DOI:10.14048/j.issn.1671-2579.2026.05.002 文章编号:1671-2579(2026)05-0010-11

基于正交试验法的IHCS-BP神经网络边坡稳定性预测模型

肖雅蕊[1],马缤辉[1,2*],兰天[1],马明磊[3],黄厚卿[4],向泽世[1],李湘蓉[1]

(1.湖南科技大学 土木工程学院,湖南 湘潭 411201;2.湖南科技大学 岩土工程稳定控制与健康监测湖南省重点实验室,湖南 湘潭 411201;3.中建八局工程研究院,上海市 200000;
4.中交二航局第二工程有限公司,重庆市 401121)

摘要:针对传统边坡稳定性分析方法难以量化多因素耦合作用及神经网络预测精度不足的问题,该文提出一种基于正交试验设计法的IHCS-BP神经网络预测模型。通过正交试验分析黏聚力、内摩擦角等6个因素的敏感性并确定其排序;结合IHCS算法动态优化BP网络权重以提升模型全局寻优能力,构建IHCS-BP预测模型;利用81组正交试验数据验证模型可行性,并通过24组实际边坡案例验证其泛化性能。结果表明:各影响因素敏感性排序为边坡坡角>内摩擦角>黏聚力>边坡高度>孔隙压力比>重度;在81组正交试验数据中,IHCS-BP模型的训练集均方根误差E_{RMSE}(0.084)与测试集均方根误差E_{RMSE}(0.182)较传统BP模型降低60%以上;实际应用结果显示,IHCS-BP模型预测误差(E_{MAPE}=9.365%)显著优于4个对比模型,优化后的模型预测精度更高。研究结果可为复杂边坡工程提供参考。

关键词:边坡稳定性;正交试验设计;敏感性分析;BP神经网络;预测
中图分类号:U416.1 **文献标志码:**A

A slope stability prediction model using IHCS-BP neural network based on orthogonal experimental method

Xiao Yarui[1], Ma Binhui[1,2*], Lan Tian[1], Ma Minglei[3], Huang Houqing[4], Xiang Zeshi[1], Li Xiangrong[1]

(1. School of Civil Engineering, Hunan University of Science and Technology, Xiangtan, Hunan 411201, China; 2. Hunan Province Key Laboratory of Geotechnical Engineering Stability Control and Health Monitoring, Hunan University of Science and Technology, Xiangtan, Hunan 411201, China; 3. China Construction Eighth Engineering Division Co., Ltd., Shanghai 200000, China;
4. China Communications 2nd Navigational Bureau 2nd Engineering Co., Ltd., Chongqing 401121, China)

Abstract: To address the problems that traditional slope stability analysis methods struggle to quantify the coupling effect of multiple factors and that neural network prediction accuracy is insufficient, an IHCS-BP neural network prediction model based on orthogonal experimental design was proposed. Through orthogonal experiments, the sensitivity of six factors including cohesion and internal friction angle was analyzed, and their ranking was determined. The IHCS algorithm was employed for dynamically optimizing the weights of the BP network to improve the global optimization capability of the model, and the IHCS-BP prediction model was built. A total of 81 groups of orthogonal experimental data were used to verify the feasibility of the model, and 24 groups of actual slope cases were adopted to verify its generalization performance. The results show that the sensitivity of the influencing factors is in order of slope angle > internal friction angle > cohesion > slope height > pore pressure ratio > unit weight. In the 81 groups of orthogonal experimental data, the training set root mean square error (E_{RMSE}, 0.084) and test set E_{RMSE} (0.182) of the IHCS-BP model are reduced by more than 60% compared with those of the traditional BP model. The actual application results show that the prediction error of the IHCS-BP model (E_{MAPE} = 9.365%) is significantly lower than those of the four comparison models, and the optimized model

收稿日期:2025-02-27 **修回日期:**2026-04-19
基金项目:湖南省自然科学基金资助项目(编号:2022JJ30258);湖南省教育厅科学研究重点项目(编号:21A0308)
作者简介:肖雅蕊,女,硕士研究生. E-mail:1195268498@qq.com
***通信作者:**马缤辉,男,博士,教授. E-mail:mbh@hnust.edu.cn

has higher accuracy in prediction. The results can provide reference for complex slope engineering.

Keywords: slope stability; orthogonal experimental design; sensitivity analysis; BP neural network; prediction

0　引言

边坡稳定性是道路工程中的关键问题，直接关系到道路的安全性、耐久性和使用寿命。在道路建设过程中，边坡失稳可能导致严重的安全事故，如滑坡[1]、坍塌等，不仅会破坏道路结构，还会对周边环境和交通造成严重影响。因此，准确评估边坡稳定性是道路工程设计和施工中不可或缺的环节[2]。

传统的边坡稳定性分析方法主要包括极限平衡法、有限元法以及数值模拟等[3-4]，这些方法虽然在理论上具有一定的严谨性，但往往依赖于大量的假设条件、边界约束，且计算过程烦琐复杂。而边坡稳定性评价涉及许多变量，安全系数的计算需要边坡几何尺寸、地质材料指标及其剪切强度参数、孔隙水压力信息等数据[5]，但是传统方法在处理这些非线性、多变量耦合关系时存在一定局限性。

随着人工智能技术的发展，神经网络凭借其非线性映射能力，为边坡稳定性预测中的多因素耦合及数据不确定性等问题提供了新的解决方法。BP神经网络因结构简单、非线性映射能力强等优势被广泛应用，但其收敛速度慢、泛化能力弱等问题限制了实际应用效果[6]。为此，需对BP神经网络进行优化改进，以提升其在边坡稳定性分析中的预测精度与效率。王彪龙等[7]采用基于自然选择PSO算法优化BP神经网络的权值和阈值，结果表明优化后的模型具有更高的拟合精度，误差更小；尹斐[8]采用改进的烟花算法（FWADM）对BP神经网络进行了优化，经过优化的BP神经网络精度得到了提高；邓智中等[9]采用遗传算法对神经网络的初始权、阈值进行了筛选优化，结果表明优化后的模型既提高了学习训练效率，又使得传统BP神经网络模型的精度大大提高；董建华[10]采用改进的粒子群算法优化BP神经网络模型，结果表明优化后的神经网络模型具有更好的收敛精度和预测精度；胡卫东等[11]通过改进粒子群算法优化BP神经网络的权值和阈值，利用动态变化的惯性权重加快了网络的收敛速度，有效提升了边坡稳定性评价的效率和准确性；李龙等[12]对传统BP神经网络在边坡稳定性预测方面收敛速度慢和易陷入局部最小值的局限性，提出了融合附加动量法和自适应学习速率法以加速收敛，并引入模拟退火算法以增强全局搜索能力的改进模型，试验表明该模型有效提高了预测精度和计算效率；Wang等[13]提出了一种改进的麻雀搜索算法，通过引入动态权重因子和反向学习策略两方面的改进来优化BP神经网络的边坡安全系数预测模型（ISSA-BP），该模型改善了算法容易陷入局部区域的缺点，获得了逆向解；胡少伟等[14]提出了一种改进的PSO-BP神经网络模型，用于提高边坡稳定性的预测精度和收敛速度；莫勇刚等[15]为了避免结果陷入局部最小值，在调整权值与阈值时加入动量项，又为了加快收敛速度采用了可变的学习速度VLBP加以改进BP神经网络。

正交试验作为一种高效的多因素试验设计方法，在边坡工程中得到了广泛应用。韦立德等[16]在对输电线路塔基边坡稳定性安全系数进行预测研究中，运用正交试验方法与人工神经网络模型相结合的方式构建了预测模型，结果表明，人工神经网络方法在边坡稳定性安全系数计算方面具有较高的有效性；衣瑛等[17]通过正交设计方法得到3种边坡稳定性影响因素的三水平正交设计表，运用极限平衡法计算不同组合条件下的边坡安全系数。分析显示，内摩擦角对排土场边坡稳定性的影响最为显著，超过散体的重度和内聚力；翟明洋等[18]基于Abaqus的强度折减有限元法，结合正交设计和灰色关联分析法，对某均质边坡的6个主要影响因素进行了敏感性分析，并确定了各因素的敏感性排序。

Ghodrati等[19]提出一种混合杜鹃搜索算法（HCS），将CS和PSO结合，具有良好的优化性能。本文利用其思想将PSO算法与马技等[20]提出的一种改进的布谷鸟搜索算法（ICS）结合形成IHCS算法，再利用该算法对BP神经网络进行优化，构建一种基于正交试验设计法与改进布谷鸟搜索算法（IHCS）优化的BP神经网络边坡稳定性预测模型。首先通过正交试验量化黏聚力、内摩擦角等6个关键因素的敏感性排序，明确主控因子；其次，结合IHCS算法动态调节BP神经网络权重，提升全局寻优能力；最终，利用实际边坡数据验证模型泛化性能。

1　边坡影响因素敏感性分析

在边坡稳定性分析中，极限平衡法虽然能够通

过计算稳定性系数评估边坡的稳定状态，但其局限性在于无法量化各影响因素对边坡稳定性的具体贡献程度，为了克服这一局限性，本节采用正交试验分析法对同一单层均质边坡进行稳定性影响因素的敏感性分析，通过这种方法，明确各因素对边坡稳定性的影响程度，为实际边坡工程的设计优化和治理防护提供理论依据，从而提高边坡开挖和使用的安全性、经济性和可靠性。

1.1 边坡影响因素范围选取

首先根据与边坡稳定性相关的内在因素和外在因素，参考相关研究文献[8-15]选取影响边坡稳定性的因素：黏聚力c、内摩擦角φ、重度γ、边坡坡角α、边坡高度H与孔隙压力比r_u 6个因素，其次归纳了6个影响因素的分布范围[21]（表1）。

表1 边坡影响因素分布区间

Table 1 Distribution ranges of slope influencing factors

黏聚力c/kPa	内摩擦角φ/(°)	重度γ/(kN·m^{-3})	边坡坡角α/(°)	边坡高度H/m	孔隙压力比r_u
10～50	10～50	16～24	15～55	10～30	0.1～0.5

1.2 正交试验分析法

正交试验设计[22]是一种基于正交表的高效多因素试验方法，其核心思想是通过均衡分散性和整齐可比性原则，从全部可能的参数组合中选取具有代表性的少量试验方案，从而以最少试验次数揭示多因素对目标变量的主效应及交互作用。

为了尽量减少误差，本文在选择试验方案时，采用了随机方法来安排所选取的6个因素的水平，在分析计算过程中，每个因素都被分配了9个不同的水平，具体见表2。

表2 边坡稳定性影响因素的正交试验水平分布表

Table 2 Orthogonal experimental levels of influencing factors for slope stability

水平	因素					
	c/kPa	φ/(°)	γ/(kN·m^{-3})	α/(°)	H/m	r_u
1	10	10	16	15	10.0	0.10
2	15	15	17	20	12.5	0.15
3	20	20	18	25	15.0	0.20
4	25	25	19	30	17.5	0.25
5	30	30	20	35	20.0	0.30
6	35	35	21	40	22.5	0.35
7	40	40	22	45	25.0	0.40
8	45	45	23	50	27.5	0.45
9	50	50	24	55	30.0	0.50

依据正交试验设计中的因素水平表2，本研究选用了$L_{81}(9^6)$正交表来进行试验。依托Slide数值模拟平台，运用M-P强度折减法系统求解正交表中81组试验的边坡安全系数F_s，所有试验的计算结果见表3。

1.3 正交试验结果分析

1.3.1 极差结果分析

利用SPSSAU软件，计算正交试验结果（表3）中6个因素在9个水平下的极差值，SPSSAU软件输出的极差分析表格，将列出各项指标，包括K值、k值、最佳水平、R值、水平数量和每水平重复数r，各个指标的意义说明如下：K值为某因素某水平时试验数据求和；k值为对应的平均值；最佳水平指某因子时最佳k值对应的水平编号[23]；R指因素的极差值，该值指某因素时，k最大值减去k最小值，可结合因素极差值对比各因素的优劣；水平数量指某因素的水平数；每水平重复数r指水平的平均试验重复次数。各个指标相关结果见表4。

从表4可以看出：① k值：黏聚力随着水平增加，k值总体上升，表明较高的黏聚力有助于提高边坡稳定性；内摩擦角φ的k值随水平升高而增加，表明较大的内摩擦角能有效提升稳定系数；重度γ的k值变化不明显，说明其对F_s影响较小；边坡坡角α的k值随着其角度增大而降低，说明较大的边坡坡角会降低边坡稳定性；边坡高度H的k值没有明显趋势，表明其对F_s的影响较为复杂；孔隙压力比r_u的k值随着水平增大而下降，表明较高的孔隙水压力会降低边坡的稳定性。② 最佳水平：边坡角取较小值（水平1）时，稳定系数较高，而较高的内摩擦角（水平9）有助于提高稳定性。③ R值：极差值R越大，表明该因素对边坡稳定性影响越显著。边坡坡角的R值最大，为1.68，说明其对稳定系数F_s影响最显著，内摩擦角的R值为1.52，次于边坡坡角，也对稳定性有较大影响，黏聚力的R值为0.96，影响排名第3，边坡高度和孔隙压力比的R值较低，分别为0.71和0.58，表明其对稳定性的影响较小，重度影响最小，R值仅为0.49，说明重度对边坡稳定性的贡献较弱，故可得到敏感性高低排序为：边坡坡角α＞内摩擦角φ＞黏聚力c＞边坡高度H＞孔隙压力比r_u＞重度γ。

表3　正交表$L_{81}(9^6)$及边坡安全系数F_s

Table 3　Orthogonal table $L_{81}(9^6)$ and slope safety factor F_s

序号	c/kPa	φ/(°)	γ/(kN·m^{-3})	α/(°)	H/m	r_u	F_s	序号	c/kPa	φ/(°)	γ/(kN·m^{-3})	α/(°)	H/m	r_u	F_s
1	2	1	9	5	4	7	0.452	42	1	1	1	1	1	1	1.328
2	5	8	1	6	2	7	1.918	43	9	6	1	8	3	4	1.976
3	1	9	3	6	6	4	1.344	44	4	9	7	8	5	5	1.172
4	3	4	1	7	8	9	0.532	45	4	5	9	1	7	8	1.817
5	8	1	2	3	5	9	1.213	46	9	1	7	4	8	6	0.882
6	7	5	4	6	9	9	0.859	47	8	2	4	9	2	1	1.466
7	4	8	5	2	8	1	3.340	48	4	2	1	3	9	6	0.901
8	2	3	4	8	7	6	0.431	49	9	7	2	6	7	1	2.142
9	3	6	8	1	2	5	2.897	50	2	7	1	4	6	5	1.540
10	2	2	2	2	1	2	1.572	51	5	9	6	3	8	2	3.058
11	3	2	7	6	4	8	0.570	52	3	5	6	4	5	1	1.546
12	9	4	6	5	9	8	1.026	53	8	4	7	1	6	2	2.716
13	9	3	5	7	2	2	1.791	54	6	3	7	5	3	1	1.466
14	9	2	3	1	5	7	1.980	55	1	4	9	2	2	6	1.305
15	5	1	4	7	6	8	0.565	56	6	5	1	9	4	2	1.333
16	2	8	6	1	3	9	2.641	57	7	1	6	8	2	3	1.137
17	4	7	3	5	2	9	1.504	58	7	4	2	9	3	5	1.269
18	7	2	8	5	8	4	0.862	59	6	1	3	2	9	5	0.995
19	9	9	9	9	1	9	1.545	60	6	9	2	4	2	8	2.662
20	8	6	5	4	9	7	1.488	61	6	7	4	1	8	3	3.675
21	7	9	5	1	4	6	4.610	62	5	6	7	2	7	9	1.620
22	2	5	7	3	2	4	1.630	63	6	8	9	7	5	4	1.447
23	4	6	2	7	4	3	1.360	64	5	3	2	1	9	4	1.824
24	1	3	8	4	4	9	0.555	65	1	7	5	3	3	8	1.390
25	5	7	8	9	5	6	0.823	66	8	7	6	2	4	4	3.270
26	7	6	9	3	6	1	2.375	67	3	8	2	5	6	6	1.477
27	7	8	3	4	7	2	2.618	68	6	2	5	8	6	9	0.585
28	1	8	7	9	9	3	0.690	69	8	3	9	6	8	5	0.884
29	2	6	3	9	8	8	0.391	70	4	4	4	4	1	4	1.836
30	1	6	4	5	5	2	1.237	71	9	5	8	2	6	3	2.472
31	6	6	6	6	1	6	1.881	72	4	3	6	9	6	7	0.482
32	3	9	4	2	3	7	2.962	73	8	8	8	8	1	8	1.729
33	1	5	2	8	8	7	0.407	74	4	1	8	6	3	2	0.766
34	8	9	1	5	7	3	2.634	75	9	8	4	3	4	5	3.172
35	7	3	1	2	5	8	1.730	76	1	2	6	7	7	5	0.356
36	2	4	5	6	5	3	0.857	77	5	4	3	8	4	1	1.190
37	6	4	8	3	7	7	1.245	78	5	5	5	5	1	5	1.883
38	5	2	9	4	3	3	1.155	79	3	3	3	3	1	3	1.732
39	8	5	3	7	3	6	1.586	80	3	7	9	8	9	2	0.941
40	3	1	5	9	7	4	0.383	81	7	7	7	7	1	7	1.807
41	2	9	8	7	9	1	1.442								

1.3.2　方差结果分析

利用SPSS软件对正交试验结果表3中6个因素进行方差计算,结果如表5所示。

从表5中F的大小,可得到敏感性高低排序为:边坡坡角α>内摩擦角φ>黏聚力c>边坡高度H>孔隙压力比r_u>重度γ。表5中Ⅲ类平方和与均方是

评估每个因素对因变量的影响，它们的值越大，表明该因素对因变量的影响越大，边坡坡角和内摩擦角Ⅲ类平方和与均方的值最大，说明其对边坡安全系数的影响最大，而重度对边坡安全系数的影响最小。从表中还能看出所有因素的显著性水平都小于0.001，表明这些因素对因变量都有显著影响。

表4 正交试验极差分析

Table 4 Range analysis of orthogonal experiment

项	水平	因子1（c）	因子2（φ）	因子3（γ）	因子4（α）	因子5（H）	因子6（r_u）
K值	1	8.61	7.72	13.89	23.49	15.31	16.29
	2	10.96	9.45	13.93	19.27	16.31	16.03
	3	13.04	10.89	13.34	16.72	15.21	15.71
	4	13.18	11.98	16.20	14.28	16.51	14.57
	5	14.04	13.53	16.33	12.54	12.00	14.17
	6	15.29	15.23	15.40	11.22	13.56	13.90
	7	17.27	17.09	12.55	10.89	13.25	12.74
	8	16.99	19.03	12.79	9.57	14.03	11.88
	9	16.99	21.43	11.92	8.38	10.17	11.05
k值	1	0.96	0.86	1.54	2.61	1.70	1.81
	2	1.22	1.05	1.55	2.14	1.81	1.78
	3	1.45	1.21	1.48	1.86	1.69	1.75
	4	1.46	1.33	1.80	1.59	1.83	1.62
	5	1.56	1.50	1.81	1.39	1.33	1.57
	6	1.70	1.69	1.71	1.25	1.51	1.54
	7	1.92	1.90	1.39	1.21	1.47	1.42
	8	1.89	2.11	1.42	1.06	1.56	1.32
	9	1.89	2.38	1.32	0.93	1.13	1.23
最佳水平		7	9	5	1	4	1
R		0.96	1.52	0.49	1.68	0.71	0.58
水平数量		9	9	9	9	9	9
每水平重复数r		9	9	9	9	9	9

表5 正交试验方差分析

Table 5 Analysis of variance for orthogonal experiment

评价指标因素	Ⅲ类平方和	自由度	均方	F	显著性
c	7.783	8	0.973	19.370	<0.001
φ	18.408	8	2.301	45.812	<0.001
γ	2.282	8	0.285	5.679	<0.001
α	21.772	8	2.722	54.185	<0.001
H	3.808	8	0.476	9.476	<0.001
r_u	3.049	8	0.381	7.587	<0.001

综上，通过正交试验极差和方差分析法可以确定边坡稳定性影响因素敏感性大小排序为：边坡坡角α＞内摩擦角φ＞黏聚力c＞边坡高度H＞孔隙压力比r_u＞重度γ。

2 IHCS-BP神经网络模型构建

2.1 IHCS-BP神经网络模型原理

基于正交试验设计法与改进布谷鸟搜索算法（IHCS）优化的BP神经网络边坡稳定性预测模型原理如下：

（1）初始化相关参数和变量。设置混合优化参数：种群规模、搜索边界、最大迭代次数、惯性权重、个体学习因子、社会学习因子。初始化BP网络结构参数：输入维度、隐层单元数、输出维度。

（2）初始化混合种群。生成均匀分布的初始巢穴位置，每个巢穴编码包含神经网络全部连接权重；随机初始化粒子速度；建立个体最优解和全局最优解存储机制。

（3）定义适应度函数。用来评估每个巢穴位置（即神经网络权重和偏置组合）的优劣，采用归一化后的均方误差作为评估标准。

（4）改进布谷鸟搜索优化（ICS）。以自适应步长调节、动态发现概率、莱维飞行更新方法进行个体和全局最优位置更新[20]。

（5）PSO群体智能扰动。引入粒子群优化机制进行二次更新即通过式（1）～（2）更新个体和全局最优的速度和位置。

第$t+1$代粒子i的速度$v_{i,d}^{(t+1)}$和位置$x_{i,d}^{(t+1)}$使用以下公式计算：

$$v_{i,d}^{(t+1)}=\omega\cdot v_{i,d}^{(t)}+c_1\cdot r_1\cdot\left(p_{i,d}^{\text{best}}-x_{i,d}^{(t)}\right)+c_2\cdot r_2\cdot\left(p_{g,d}^{\text{best}}-x_{i,d}^{(t)}\right) \tag{1}$$

式中：$v_{i,d}^{(t)}$为粒子i在第t代的速度；$x_{i,d}^{(t)}$为粒子i在第t代的位置；$p_{i,d}^{\text{best}}$为粒子i迄今为止的最佳位置（即其自身历史最佳解）；$p_{g,d}^{\text{best}}$为群体中最优的粒子位置（全局最优解）；ω为惯性权重，控制粒子的动量；c_1和c_2为学习因子（加速常数），通常为常数；r_1和r_2为在[0,1]范围内的随机数，用于引入随机性；d为空间维度，$1\leqslant d\leqslant D$。

位置更新公式：

$$x_{i,d}^{(t+1)}=x_{i,d}^{(t)}+v_{i,d}^{(t+1)} \tag{2}$$

（6）更新权重和偏置。使用反向传播算法来计算误差并更新神经网络的权重和偏置。

（7）迭代更新。重复步骤（4）～（6），直到达到最大迭代次数。

(8)输出最优解。在所有迭代结束后,选择适应度最优的巢穴位置,即最优的神经网络权重和偏置,返回最终优化得到的最优权重和偏置,训练完成的BP神经网络即可用于预测任务。

IHCS-BP算法的整体流程图如图1所示。

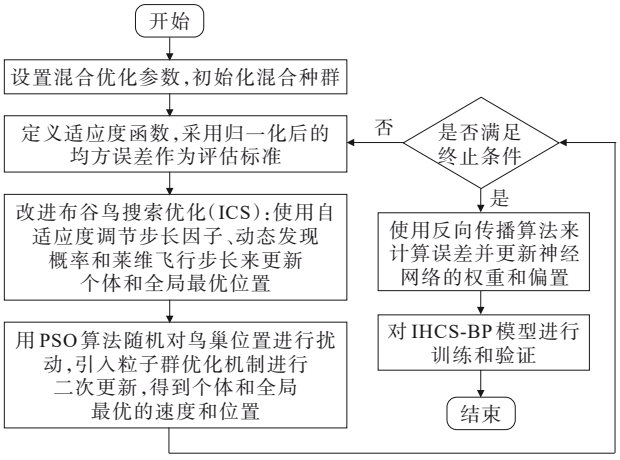

图1　IHCS-BP算法流程图

Figure 1　Flow chart of IHCS-BP algorithm

2.2　神经网络模型评价指标

评估模型精确程度通常依赖于若干具体的性能指标,本文采用以下几个指标来衡量模型的精确度,其中:y_i为实际值;y_j为预测值;n为样本数量。

(1)均方根误差(Root Mean Square Error)

$$E_{\mathrm{RMSE}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-y_j)^2} \tag{3}$$

(2)均方误差(Mean Square Error)

$$E_{\mathrm{MSE}}=\frac{1}{n}\sum_{i=1}^{n}(y_i-y_j)^2 \tag{4}$$

(3)平均绝对误差(Mean Absolute Error)

$$E_{\mathrm{MAE}}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-y_j\right| \tag{5}$$

(4)平均绝对百分比误差(Mean Absolute Percentage Error)

$$E_{\mathrm{MAPE}}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i-y_j}{y_i}\right|\times 100\% \tag{6}$$

2.3　神经网络模型参数确定

本研究构建的边坡稳定性预测模型采用3层BP神经网络结构,其中输入层包含6个神经元,分别对应6个特征参数,输出层则设置1个神经元用于表示稳定性预测结果。隐含层神经元个数通过式(7)计算确定,得到隐含层神经元个数s=12。

$$s=\sqrt{m+e}+a \tag{7}$$

式中:m为输入层节点个数;e为输出层节点个数;a为0~10之间的常数。

取m=6,e=1,网络的训练设置如下:学习率设置为0.001,最大迭代次数设定为1 000次,目标最小误差值设定为0.000 65;在BP神经网络预测模型中,输入层、输出层采用双曲正切函数(Tanh)作为激活函数[24]。IHCS神经网络模型迭代次数为2 100次,惯性权重为0.4,学习因子c_1、c_2均为1.5,种群规模为25,发现概率的最小值为0.1,最大值为0.75,搜索空间的下边界为−1,上边界为1。

3　IHCS-BP神经网络模型可行性分析

选取正交试验表3中共81组试验样本,6个因子对应的具体数据如表6所示,按8:2的比例将前1~65组及边坡安全系数结果作为训练样本,66~81组作为检验样本。

表6　边坡稳定性样本数据

Table 6　Slope stability sample data

序号	γ/(kN·m^{-3})	c/kPa	φ/(°)	α/(°)	H/m	r_u	F_s	序号	γ/(kN·m^{-3})	c/kPa	φ/(°)	α/(°)	H/m	r_u	F_s
1	24	15	10	35	17.5	0.40	0.452	42	16	10	10	15	10	0.10	1.328
2	16	30	45	40	12.5	0.40	1.918	43	16	50	35	50	15	0.25	1.976
3	18	10	50	40	22.5	0.25	1.344	44	22	25	50	50	20	0.30	1.172
4	16	20	25	45	27.5	0.50	0.532	45	24	25	30	15	25	0.45	1.817
5	17	45	10	25	20.0	0.50	1.213	46	22	50	10	30	27.5	0.35	0.882
6	19	40	30	40	30.0	0.50	0.859	47	19	45	15	55	12.5	0.10	1.466
7	20	25	45	20	27.5	0.10	3.340	48	16	25	15	25	30	0.35	0.901
8	19	15	20	50	25.0	0.35	0.431	49	17	50	40	40	25	0.10	2.142
9	23	20	35	15	12.5	0.30	2.897	50	16	15	40	30	22.5	0.30	1.540
10	17	15	15	20	10.0	0.15	1.572	51	21	30	50	25	27.5	0.15	3.058
11	22	20	15	40	17.5	0.45	0.570	52	21	20	30	30	20.0	0.10	1.546

续表6

序号	γ/(kN·m^{-3})	c/kPa	φ/(°)	α/(°)	H/m	r_u	F_s	序号	γ/(kN·m^{-3})	c/kPa	φ/(°)	α/(°)	H/m	r_u	F_s
12	21	50	25	35	30.0	0.45	1.026	53	22	45	25	15	22.5	0.15	2.716
13	20	50	20	45	12.5	0.15	1.791	54	22	35	20	35	15.0	0.10	1.466
14	18	50	15	15	20.0	0.40	1.980	55	24	10	25	20	12.5	0.35	1.305
15	19	30	10	45	22.5	0.45	0.565	56	16	35	30	55	17.5	0.15	1.333
16	21	15	45	15	15.0	0.50	2.641	57	21	40	10	50	12.5	0.20	1.137
17	18	25	40	35	12.5	0.50	1.504	58	17	40	25	55	15.0	0.30	1.269
18	23	40	15	35	27.5	0.25	0.862	59	18	35	10	20	30.0	0.30	0.995
19	24	50	50	55	10.0	0.50	1.545	60	17	35	50	30	12.5	0.45	2.662
20	20	45	35	30	30.0	0.40	1.488	61	19	35	40	15	27.5	0.20	3.675
21	20	40	50	15	17.5	0.35	4.610	62	22	30	35	20	25.0	0.50	1.620
22	22	15	30	25	12.5	0.25	1.630	63	24	35	45	45	20.0	0.25	1.447
23	17	25	35	45	17.5	0.20	1.360	64	17	30	20	15	30.0	0.25	1.824
24	23	10	20	30	17.5	0.50	0.555	65	20	10	40	25	15.0	0.45	1.390
25	23	30	40	55	20.0	0.35	0.823	66	21	45	40	20	17.5	0.25	3.270
26	24	40	35	25	22.5	0.10	2.375	67	17	20	45	35	22.5	0.35	1.477
27	18	40	45	30	25.0	0.15	2.618	68	20	35	15	50	22.5	0.50	0.585
28	22	10	45	55	30.0	0.20	0.690	69	24	45	20	40	27.5	0.30	0.884
29	18	15	35	55	27.5	0.45	0.391	70	19	25	25	30	10.0	0.25	1.836
30	19	10	35	35	20.0	0.15	1.237	71	23	50	30	20	22.5	0.20	2.472
31	21	35	35	40	10.0	0.35	1.881	72	21	25	20	55	22.5	0.40	0.482
32	19	20	50	20	15.0	0.40	2.962	73	23	45	45	50	10.0	0.45	1.729
33	17	10	30	50	27.5	0.40	0.407	74	23	25	10	40	15.0	0.15	0.766
34	16	45	50	35	25.0	0.20	2.634	75	19	50	45	25	17.5	0.30	3.172
35	16	40	20	20	20.0	0.45	1.730	76	21	10	15	45	25.0	0.30	0.356
36	20	15	25	40	20.0	0.20	0.857	77	18	30	25	50	17.5	0.10	1.190
37	23	35	25	25	25.0	0.40	1.245	78	20	30	30	35	10.0	0.30	1.883
38	24	30	15	30	15.0	0.20	1.155	79	18	20	20	25	10.0	0.20	1.732
39	18	45	30	45	15.0	0.35	1.586	80	24	20	40	50	30.0	0.15	0.941
40	20	20	10	55	25.0	0.25	0.383	81	22	40	40	45	10.0	0.40	1.807
41	23	15	50	45	30.0	0.10	1.442								

进行模型训练之前，采用式(8)对样本数据进行归一化处理。IHCS-BP神经网络模型的训练过程如图2所示。

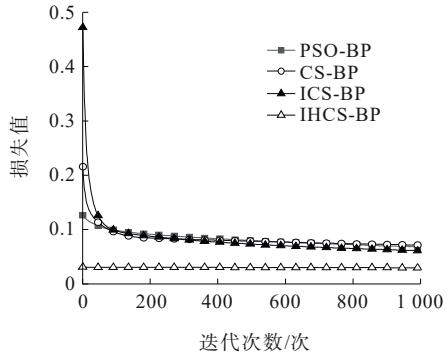

图2 神经网络训练损失曲线

Figure 2 Neural network training loss curves

$$x'=\frac{x-x_{\min}}{x_{\max}-x_{\min}} \tag{8}$$

式中：x为原始数据值；x_{max}为数据集中的最大值；x_{min}为数据集中的最小值。

从图2可以看出：4种神经网络模型的损失值均随着迭代次数的增加而逐渐减小，表明模型在不断学习和优化。其中，IHCS-BP神经网络模型的损失值始终保持在最低水平，且在迭代初期迅速下降，表现出优异的收敛速度和稳定性，这表明IHCS-BP神经网络模型在处理该问题时具有更好的优化能力和泛化性能。

4种模型训练结果的预测值与实际值的对比如图3所示，该图直观地展示了神经网络模型的拟合效果。同时，表7详细列出了训练集在各项评价指标上

的具体表现,为评估模型性能提供了量化依据。

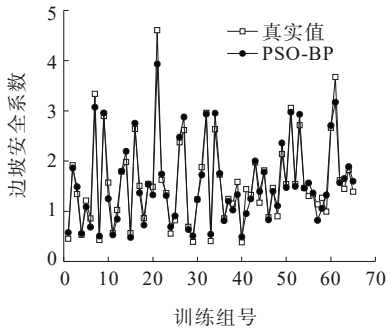

(a) PSO-BP神经网络训练结果

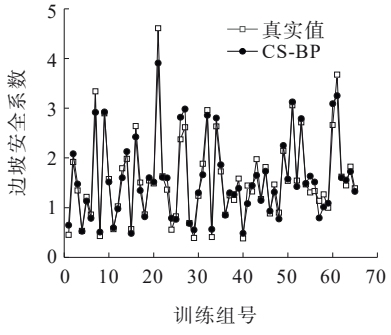

(b) CS-BP神经网络训练结果

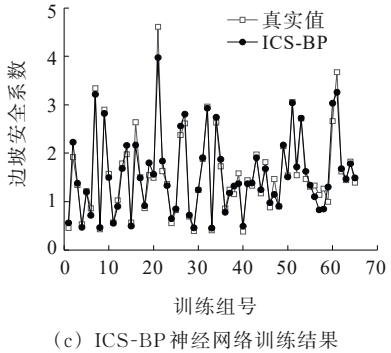

(c) ICS-BP神经网络训练结果

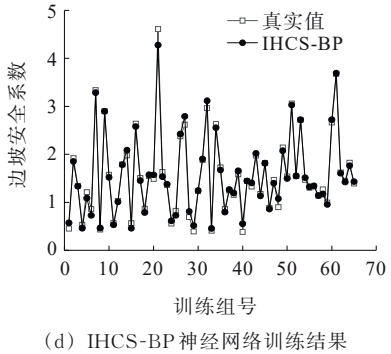

(d) IHCS-BP神经网络训练结果

图3　不同优化算法的神经网络训练效果对比

Figure 3　Comparison of neural network training effects of different optimization algorithms

由表7可知:IHCS-BP神经网络训练集E_{RMSE}为0.084,E_{MSE}为0.007,E_{MAE}为0.062,E_{MAPE}为6.028%。结果表明IHCS-BP神经网络模型在训练集上表现优于其他4种神经网络模型,其误差最小。

表7　训练集性能评估指标

Table 7　Training set performance evaluation metrics

预测模型	E_{RMSE}	E_{MSE}	E_{MAE}	E_{MAPE}/%
BP	0.231	0.053	0.168	11.910
PSO-BP	0.192	0.037	0.144	11.140
CS-BP	0.202	0.041	0.150	11.100
ICS-BP	0.182	0.033	0.129	9.248
IHCS-BP	0.084	0.007	0.062	6.028

测试集评价指标如表8所示,神经网络测试集预测结果与真实值对比如图4所示。

表8　测试集性能评估指标

Table 8　Test set performance evaluation metrics

预测模型	E_{RMSE}	E_{MSE}	E_{MAE}	E_{MAPE}/%
BP	0.249	0.062	0.202	14.540
PSO-BP	0.235	0.055	0.194	14.430
CS-BP	0.234	0.055	0.184	12.820
ICS-BP	0.198	0.039	0.136	9.739
IHCS-BP	0.182	0.033	0.132	9.085

由表8可知:IHCS-BP神经网络测试集E_{RMSE}为0.182,E_{MSE}为0.033,E_{MAE}为0.132,E_{MAPE}为9.085%。5种神经网络预测模型中IHCS-BP神经网络模型的误差均小于其他4种模型,表明本文提出的IHCS-BP神经网络模型在预测边坡稳定性方面,无论是精度还是稳定性,都要优于其他4种模型,验证了优化方式的可行性。

4　IHCS-BP神经网络模型实际应用

为了使模型预测性能更好且预测结果更有说服力,本研究从国内外研究文献中广泛收集了24组边坡稳定性指标数据进行边坡安全系数预测[25-30]。详细数据见表9。

综合重度、黏聚力与内摩擦角的数据可知该样本组包含了多种均质边坡类型;从坡角整体数据来看,样本集涵盖缓坡(15°~30°)、中坡(30°~45°)、陡坡(>45°);从坡高整体数据来看,该组数据也涵盖了多种高度边坡;综合分析边坡各影响因素可知,该数据库由不同类型的边坡样本构成,验证了数据集的合理性与可靠性。

利用已经训练好的IHCS-BP神经网络模型预测这24组边坡的安全系数,并与BP、PSO-BP、CS-BP、ICS-BP神经网络模型预测结果进行对比,IHCS-BP神经网络模型预测结果见图5,5种神经网络预测误差对比见表10。

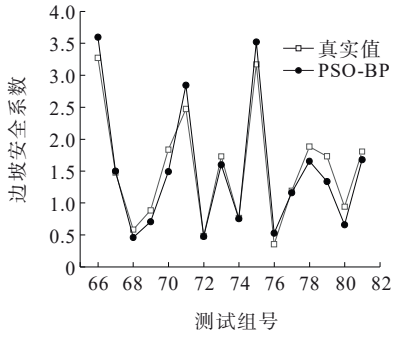

（a）PSO-BP神经网络预测结果

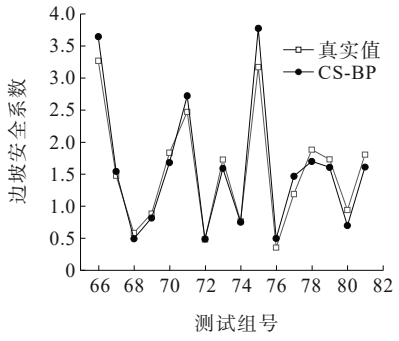

（b）CS-BP神经网络预测结果

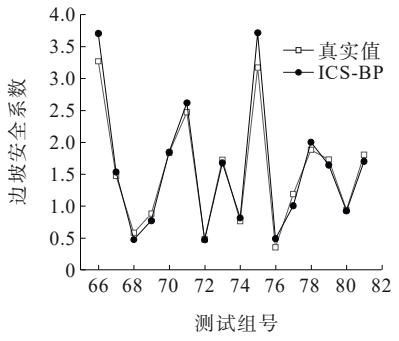

（c）ICS-BP神经网络预测结果

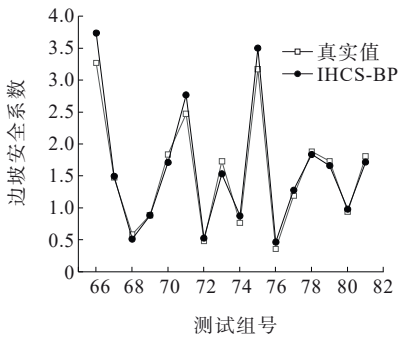

（d）IHCS-BP神经网络预测结果

图4 不同优化算法的神经网络测试效果对比

Figure 4 Comparison of neural network test performance of different optimization algorithms

从图5可以看出，IHCS-BP神经网络预测值与实际值比较贴近；从表10可以看出，IHCS-BP神经网络预测模型对于24组边坡安全系数预测结果的E_{RMSE}为0.198，E_{MSE}为0.039，E_{MAE}为0.124，E_{MAPE}为

表9 预测样本

Table 9 Predicted samples

序号	γ/(kN·m^{-3})	c/kPa	φ/(°)	α/(°)	H/m	r_u	F_s
1	22.00	10.00	35.000	45.0	10.00	0.403	0.900
2	20.00	20.00	36.000	45.0	30.00	0.503	0.830
3	18.84	15.32	30.000	25.0	10.70	0.380	1.630
4	22.00	10.00	35.000	30.0	10.00	0.290	2.000
5	21.00	10.00	30.343	30.0	30.00	0.290	1.200
6	22.00	20.00	36.000	45.0	30.00	0.290	0.890
7	23.80	31.00	38.700	47.5	23.50	0.310	1.902
8	20.20	16.70	22.300	42.4	26.60	0.250	1.389
9	22.40	20.00	35.000	45.0	10.00	0.400	0.932
10	22.00	23.40	40.000	40.0	15.00	0.300	1.450
11	22.00	24.90	24.000	46.7	18.20	0.350	1.004
12	18.00	28.40	13.400	34.5	18.02	0.200	1.230
13	18.50	35.10	10.100	30.0	25.50	0.250	1.090
14	20.00	35.00	30.000	50.0	24.00	0.260	1.792
15	20.40	24.91	13.000	22.0	10.70	0.350	1.400
16	19.60	12.00	20.000	22.0	12.20	0.405	1.350
17	18.80	15.32	30.000	25.0	10.60	0.380	1.630
18	19.60	11.97	20.000	22.0	12.20	0.400	1.350
19	18.00	24.00	30.200	45.0	20.00	0.120	1.120
20	19.63	11.97	20.000	22.0	12.19	0.405	1.350
21	18.84	15.32	30.000	25.0	10.67	0.380	1.630
22	22.40	10.00	35.000	45.0	10.00	0.400	0.900
23	19.06	11.71	28.000	35.0	21.00	0.110	1.090
24	20.41	24.90	13.000	22.0	10.67	0.350	1.400

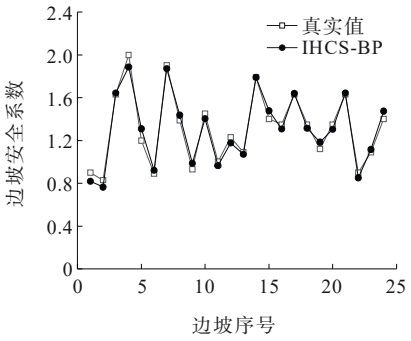

图5 IHCS-BP神经网络预测结果

Figure 5 IHCS-BP neural network prediction results

表10 预测结果比较

Table 10 Comparison of prediction results

预测模型	E_{RMSE}	E_{MSE}	E_{MAE}	E_{MAPE}/%
BP	0.357	0.127	0.230	16.77
PSO-BP	0.284	0.081	0.190	13.31
CS-BP	0.284	0.081	0.196	14.20
ICS-BP	0.271	0.073	0.136	12.42
IHCS-BP	0.198	0.039	0.124	9.365

9.365%，与其他4种模型相比均为最小，预测值与实际值也更接近，再次表明了IHCS-BP神经网络模型在边坡安全系数预测方面的有效性。

5　结论

本文通过正交试验与IHCS-BP神经网络的深度融合，系统解决了边坡稳定性分析中多因素耦合量化与预测精度提升的难题，主要结论如下：

（1）选取6个影响边坡稳定性的因素进行正交试验设计，结果表明边坡稳定性影响因素敏感性大小排序为：边坡坡角α＞内摩擦角φ＞黏聚力c＞边坡高度H＞孔隙压力比r_u＞重度γ。

（2）基于正交试验结果中的81组边坡参数采用Slide软件计算对应安全系数，并以此作为神经网络可行性分析的样本集；利用PSO算法与ICS算法建立IHCS-BP神经网络模型，测试结果表明：该模型的4项指标均优于其他4个对比模型，其E_{MAPE}（9.085%）较BP神经网络（14.54%）降低38%，验证了混合优化策略的有效性。

（3）基于24组实际边坡数据的预测结果表明，IHCS-BP神经网络预测模型的E_{RMSE}为0.198，E_{MSE}为0.039，E_{MAE}为0.124，E_{MAPE}为9.365%，均显著优于对比模型，证明其在复杂地质条件下具有高精度与鲁棒性。

（4）本研究仍存在以下局限性：样本数据集中于单层均质边坡，未来需扩展至非均质边坡及动态荷载场景；IHCS-BP算法的参数优化效率可结合深度学习框架进一步提升。

参考文献：

References：

[1] 黄洪超. 某高速公路巨型滑坡稳定性分析及处置方案研究[J]. 中外公路, 2023, 43(4): 24-29.
Huang Hongchao. Study on stability analysis and treatment of a expressway landslide[J]. Journal of China & Foreign Highway, 2023, 43(4): 24-29.

[2] 王津锋, 范胜通, 谢海波. 基于IWOA-SVM的边坡可靠度分析[J]. 中外公路, 2026, 46(1): 21-29.
Wang Jinfeng, Fan Shengtong, Xie Haibo. Slope reliability analysis based on IWOA-SVM[J]. Journal of China & Foreign Highway, 2026, 46(1): 21-29.

[3] 熊振涛. 基于机器学习的边坡稳定性预测模型优化研究[D]. 昆明: 昆明理工大学, 2023.
Xiong Zhentao. Research on optimization of slope stability prediction model based on machine learning[D]. Kunming: Kunming University of Science and Technology, 2023.

[4] 刘平, 王美静, 张少强, 等. 抗滑桩桩位对边坡稳定性影响机理的宏细观分析[J]. 中外公路, 2023, 43(3): 37-41.
Liu Ping, Wang Meijing, Zhang Shaoqiang, et al. Macro and micro analysis of influence mechanism of anti-slide pile position on slope stability[J]. Journal of China & Foreign Highway, 2023, 43(3): 37-41.

[5] 傅杨攀. 基于大数据和卷积神经网络的边坡稳定性分析[D]. 广州: 广东工业大学, 2022.
Fu Yangpan. Slope stability analysis based on big data and convolutional neural network[D]. Guangzhou: Guangdong University of Technology, 2022.

[6] 李蕾. 基于GA-LM-BP神经网络的降雨条件下边坡稳定性预测研究[D]. 长沙: 长沙理工大学, 2017.
Li Lei. Study on slope stability prediction under rainfall based on GA-LM-BP neural network[D]. Changsha: Changsha University of Science & Technology, 2017.

[7] 王彪龙, 孟凡利, 曾超, 等. 基于自然选择策略的PSO-BP神经网络的滑坡可靠性评价方法[J]. 中外公路, 2019, 39(3): 1-9.
Wang Biaolong, Meng Fanli, Zeng Chao, et al. The method of landslide reliability evaluation based on natural selection strategy of PSO-BP neural network[J]. Journal of China & Foreign Highway, 2019, 39(3): 1-9.

[8] 尹斐. 基于改进的烟花算法在边坡工程中的应用研究[D]. 荆州: 长江大学, 2022.
Yin Fei. Research on application of improved fireworks algorithm in slope engineering[D]. Jingzhou: Yangtze University, 2022.

[9] 邓智中, 田浩帆, 包太. PCA和GA-BP神经网络在边坡稳定性预测中的应用[J]. 采矿技术, 2021, 21(2): 44-48.
Deng Zhizhong, Tian Haofan, Bao Tai. Application of PCA and GA-BP neural network in slope stability prediction[J]. Mining Technology, 2021, 21(2): 44-48.

[10] 董建华. 基于改进粒子群优化算法的边坡稳定性分析[D]. 鞍山: 辽宁科技大学, 2016.
Dong Jianhua. Slope stability analysis based on improved particle swarm optimization algorithm[D]. Anshan: University of Science and Technology Liaoning, 2016.

[11] 胡卫东, 曹文贵. 基于改进粒子群算法的BP神经网络在边坡稳定性评价中的应用[J]. 湖南理工学院学报(自然科学版), 2014, 27(2): 71-76.
Hu Weidong, Cao Wengui. Application of BP neural network in the slope stability evaluation based on improved particle swarm optimization algorithm[J]. Journal of Hunan Institute of Science and Technology (Natural Sciences), 2014, 27(2): 71-76.

[12] 李龙, 高永涛, 吴顺川, 等. 综合改进BP神经网络在边坡稳定性预测中的应用[J]. 煤炭技术, 2015, 34(9): 202-205.
Li Long, Gao Yongtao, Wu Shunchuan, et al. Application of comprehensive improvement of BP neural network in stability prediction of slope[J]. Coal Technology, 2015, 34 (9): 202-205.

[13] Wang Y W, Liu D N, Dong H Y, et al. Research on a BP

neural network slope safety coefficient prediction model based on improved sparrow algorithm optimization[J]. Applied Sciences, 2023, 13(14): 8446.

[14] 胡少伟, 李原昊, 单常喜, 等 . 基于改进的PSO-BP神经网络的边坡稳定性研究[J]. 防灾减灾工程学报, 2023, 43(4): 854-861.
Hu Shaowei, Li Yuanhao, Shan Changxi, et al. Research on slope stability based on improved PSO-BP neural network[J]. Journal of Disaster Prevention and Mitigation Engineering, 2023, 43(4): 854-861.

[15] 莫勇刚, 丁德馨, 肖猛 . 改进的BP神经网络在边坡稳定性评价中的应用[J]. 矿冶, 2006, 15(2): 9-12.
Mo Yonggang, Ding Dexin, Xiao Meng. Application of improved back propagation neural network on stability evaluation of slopes[J]. Mining and Metallurgy, 2006, 15(2): 9-12.

[16] 韦立德, 安少鹏, 李鹏云, 等 . 输电线路塔基土质边坡稳定性评价的BP网络模型[J]. 电力勘测设计, 2013(2): 17-20.
Wei Lide, An Shaopeng, Li Pengyun, et al. BP network model of stability evaluation of tower foundation soil slope in transmission line[J]. Electric Power Survey & Design, 2013(2): 17-20.

[17] 衣瑛, 孙厚广, 李经科 . 基于正交设计方法排土场边坡稳定性敏感性分析[C]//中国矿业科技文汇—2014. 合肥, 2014: 510-512.
Yi Ying, Sun Houguang, Li Jingke. Sensitivity analysis of slope stability of waste dump based on orthogonal design method [C]// China Mining Science and Technology Literature-2014. Hefei, 2014: 510-512.

[18] 翟明洋, 盛建龙, 董舒, 等 . 基于正交设计和灰色关联分析法的边坡敏感性耦合分析[J]. 化工矿物与加工, 2017, 46(2): 69-72.
Zhai Mingyang, Sheng Jianlong, Dong Shu, et al. Coupled analysis of slope sensitivity based on orthogonal design and gray correlation analysis method[J]. Industrial Minerals & Processing, 2017, 46(2): 69-72.

[19] Ghodrati A, Lotfi S. A hybrid CS/PSO algorithm for global optimization[C]// Intelligent Information and Database Systems. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012: 89-98.

[20] 马技, 刘彩霞, 丁琳琳 . 基于改进布谷鸟搜索算法的矿震震源定位方法研究[J]. 地球物理学进展, 2024, 39(3): 1070-1080.
Ma Ji, Liu Caixia, Ding Linlin. Research on mining earthquake source localization method based on improved cuckoo search algorithm[J]. Progress in Geophysics, 2024, 39(3): 1070-1080.

[21] 俞社鑫 . 基于GA-PSO-RBF模型的均质土坡稳定性及可靠度预测[D]. 赣州: 江西理工大学, 2022.
Yu Shexin. Stability and reliability prediction of homogeneous soil slope based on GA-PSO-RBF model[D]. Ganzhou: Jiangxi University of Science and Technology, 2022.

[22] 方开泰, 马长兴 . 正交与均匀试验设计[M]. 北京: 科学出版社, 2001.
Fang Kaitai, Ma Changxing. Orthogonal and uniform experimental design[M]. Beijing: Science Press, 2001.

[23] 刘子宁 . 基于产品族DNA的自动化物流设备识别设计方法研究[D]. 武汉: 华中科技大学, 2021.
Liu Zining. Research on identification design method of automatic logistics equipment based on product family DNA[D]. Wuhan: Huazhong University of Science and Technology, 2021.

[24] 赵梓景 . 基于FAGSO-BP神经网络模型的软土地基沉降预测研究[D]. 湘潭: 湖南科技大学, 2023.
Zhao Zijing. Study on settlement prediction of soft soil foundation based on FAGSO-BP neural network model [D]. Xiangtan: Hunan University of Science and Technology, 2023.

[25] 王超 . 工程高边坡稳定性预测方法研究[D]. 北京: 北京交通大学, 2009.
Wang Chao. Study on stability prediction method of engineering high slope[D]. Beijing: Beijing Jiaotong University, 2009.

[26] 孙荣琦 . 基于GA-PSO-BP神经网络的边坡稳定性评价研究[D]. 西安: 西安理工大学, 2024.
Sun Rongqi. Study on slope stability evaluation based on GA-PSO-BP neural network[D]. Xi'an: Xi'an University of Technology, 2024.

[27] 李昆仲 . 基于RBF神经网络的边坡稳定性评价研究: 以西藏夏比公路K85段边坡为例[D]. 西安: 长安大学, 2010.
Li Kunzhong. Study on slope stability evaluation based on RBF neural network: Taking K85 slope of Xiabi highway in Tibet as an example[D]. Xi'an: Chang'an University, 2010.

[28] 苏国韶, 宋咏春, 燕柳斌 . 高斯过程机器学习在边坡稳定性评价中的应用[J]. 岩土力学, 2009, 30(3): 675-679, 687.
Su Guoshao, Song Yongchun, Yan Liubin. Application of Gaussian process machine learning to slope stability evaluation [J]. Rock and Soil Mechanics, 2009, 30(3): 675-679, 687.

[29] 冯夏庭, 王泳嘉, 卢世宗 . 边坡稳定性的神经网络估计[J]. 工程地质学报, 1995, 3(4): 54-61.
Feng Xiating, Wang Yongjia, Lu Shizong. Neural network estimation of slope stability[J]. Journal of Engineering Geology, 1995, 3(4): 54-61.

[30] 程纬华, 乔登攀, 张磊, 等 . BP神经网络在露天矿边坡稳定性分析中的应用[J]. 矿冶, 2012, 21(2): 10-14, 36.
Cheng Weihua, Qiao Dengpan, Zhang Lei, et al. Application of BP networks in the stability analysis of slopes in the open-pit mine[J]. Mining and Metallurgy, 2012, 21(2): 10-14, 36.